

大規模交通流の次元削減による解釈： PCA/UMAP/MFDと東京オリパラコロナ 事例分析

瀬尾亨¹

¹正会員 東京工業大学環境・社会理工学院准教授 土木・環境工学系（〒152-8552 東京都目黒区大岡山
2-12-1-M1-13）

E-mail: seo.t.aa@m.titech.ac.jp (Corresponding Author)

道路ネットワーク上の交通流は非常に大規模な現象であり、その状態を直感的に解釈するのは難しい。例えば、全時刻全リンクの流率や速度が与えられるときに、ある状態がどの程度望ましいものなのか、ある状態は他のそれとどの程度類似しているのか、などの疑問に簡潔に答える方法は確立しているとはいえない。本研究では、いくつかの次元削減手法により大規模交通流の形態を解釈する。次元削減手法としては、最も基本的な主成分分析、非線形な多様体学習に基づく UMAP、交通工学固有の概念である Macroscopic Fundamental Diagram を用い、互いに比較する。それぞれの手法をオリンピックパラリンピック・COVID-19 という特異な事象を含む東京の交通データに適用し、考察する。

Key Words: Network traffic flow, dimension reduction, COVID-19, Visualization

1. はじめに

(1) 背景と目的

都市規模の交通は非常に大規模で複雑な現象である。自動車交通流を考えると、典型的には、これは空間的には都市全体の広範囲に渡って生起し 10–100m 単位で変動し、時間的には一年中・一日中に渡り生起し分–時間単位で変動する。このように巨大かつ詳細な現象は、それが全体としてどのような状態にあるのか直感的に認識・解釈するのは難しい。この解釈困難性は交通管制や計画上の実際的な課題となりうる。これは人間にとって問題であるだけでなく、統計的・機械学習的手法にとっても次元の呪いという形で問題となる。

本研究の目的は、都市規模の交通現象を直感的に認識・解釈できる方法の探求である。そして、その方法を 2021 年の東京オリンピックパラリンピック 2020（以下ではオリパラと略す）と COVID-19 という特異な事象を含む交通データに適用し、何らかの解釈を導き出す。ここで、本研究での「直感的に認識できる」という言葉は、具体的には「ある交通状態の表現が与えられたときに、他の異なる状態と一目で区別できる」ことを意味するものとする。このようなことができれば、交通状態の本質的な類似度や距離を定義できるようになり、状況把握・予測・制御などへの応用ができると期待

される。

一般に、動的に変化する交通の状態は、ある時刻の全リンク（あるいは、十分な数の地点）の流率・密度・速度（のうち 2 点）を並べたベクトルとして定量化できる。しかし、このベクトルは極めて高次元であるためそのままでは解釈困難である。また、異なる交通状態間の素朴な距離はそのベクトル同士のユークリッド距離と定義できるが、これは交通の方向などを区別できないため本質的な距離とは異なったものであると考えられる。

この高次元性による困難を解決するため、交通工学分野では Macroscopic Fundamental Diagram (MFD)¹⁾²⁾ と呼ばれる概念が用いられている。これは、道路ネットワークの状態をそのネットワーク全体の平均流率と密度（あるいはそれと等価な状態量）という 2 次元の状態量で表すものである。これにより、単純な状況では交通システムの状態を正しく簡潔に認識でき、エリア流入制御などによる単純かつ効率的な交通管制が可能になるとされている³⁾。

しかし、MFD による交通現象の低次元表現にはいくつかの問題がある。まず、MFD は本質的に異なる交通現象を同じ状態量として表現しうる。例えば、朝ピークと夕ピークのように交通の流れる方向が真逆の現象が同じ平均流率と密度を持ってしまい、MFD 上で区別できない場合がある。また、MFD のいわゆる渋滞領域

の实在は一般に疑われており、MFDが交通システムの性能劣化を適切に簡潔な形で表現できているかという点には議論の余地がある。

ところで、MFDはモデルベースの次元削減手法と位置づけられる。一方、より効率の良いデータ駆動型の次元削減手法を用いれば、より適切な交通現象の低次元表現が得られる可能性がある。本研究は、よく知られた次元削減手法である主成分分析（Principal component analysis: PCA）とUMAP（Uniform Manifold Approximation and Projection）⁴⁾を大規模交通流現象に適用し、その性質を分析する。

(2) 文献レビュー

交通状態をデータ駆動型のクラスタリングにより分析する研究は多い。例えば、酒井・赤松⁵⁾は首都高の交通状態のk-means法によるクラスタリングによりMFDと渋滞の空間パターンを分析し、渋滞推移過程に普遍的な規則性があることを見出した。馬場ら⁶⁾も同様にテンソル分解によるクラスタリング結果に基づき交通渋滞の時空間パターンを分析した。その他の交通状態をクラスタリングにより分析する研究については、これら2研究の参考文献を参照されたい。クラスタリングでは、クラスタ数をはじめとする様々なハイパーパラメータを調整する必要がある。また、交通現象は本来連続的な現象であるため、クラスタとして離散化するためには必ず恣意性が混入する。そのため、交通現象の低次元表現を得ることだけを考えるならば、連続的な次元削減手法がより適している可能性がある。

交通状態推定や予測のために各種のクラスタリングや次元削減を用いる研究も数多くなされている⁷⁾。しかし、それにより交通現象を理解・解釈する例は少ない。情報ネットワークの分析の分野では、ODフローをPCAにより次元削減し、数次元の表現でシステム全体の挙動をよく認識できるという結果が報告されている⁸⁾。

オリパラとCOVID-19が東京の交通流に及ぼした影響は明確にはなっていない。オリパラ期間中は、交通の需要・供給ともに様々な制御が加えられ、全体としては首都高速道路の渋滞量は休日並みに減少し、一般道は若干の交通量減があったと報告されている⁹⁾。しかし、交通現象の詳細な変化は不明確である。COVID-19が都市内交通流に与えた影響は警視庁の統計データなどで全体的な傾向は報告されているものの、詳細についての研究はいまだ見当たらない。

2. 方法

本研究で用いる次元削減手法の概要を述べる。

(1) PCA

PCAは非常に良く知られた古典的な次元削減手法である。本手法は、多数の変数から、互いに線形相関の少ない複数の量をもとの変数の線形和として構成する手法である。そのため、これは線形の次元削減手法と位置づけられる。

(2) UMAP


UMAPは比較的最近提案された次元削減手法である。本手法は多様体学習¹⁰⁾に基づく方法であり、その概略を以下に述べる。まず、対象とする高次元データが、低次元のユークリッド空間を持つ多様体上に分布しているとみなし、その多様体の形状を推定する。そして、元のデータのその低次元空間上での表現を得る。本手法は、他の次元削減手法と比較し、データの局所的な構造をよく保存しつつ、大域的な関係も表現できると言われている⁴⁾。さらに、計算コストが非常に小さい点も長所である。

図-1に3次元データからUMAPにより2次元表現を得る例を示す。図-1aは、3次元空間中に球面状に分布している3次元データである。分かり易くするために、各データ点に特定の色を付けてある。図-1bは、そのデータをUMAPにより次元削減し、2次元データとして表現したものである。すなわち、それぞれのデータ点の3次元座標をUMAPで2次元座標に変換し、元の色と同じ色でプロットしたものである。元の3次元データが球面という非線形な2次元空間に分布していることを正しく認識し、それを適切に表現できている。元データの本質的情報を表現できていると言えるだろう。一方、図-1cに同じデータをPCAにより次元削減し、第1主成分と第2主成分を可視化したものを示す。データの非線形な分布をうまく扱えず、不適切な表現になっている。

(3) MFD

MFDは、あるエリアの交通流に対し、エリア全体の平均流率 q と平均密度 k の間に成り立つとされる関係である。理想的な状況では、MFDは通常の地点の流率密度関係と同様に上に凸の曲線状の関係となる。PCAとUMAPはデータの特性にのみ依存したデータ駆動型の次元削減手法であるのに対し、MFDは結果の解釈性を重視したモデルベースの次元削減手法と位置づけられるだろう。

実際の交通では平均密度が大きくなるとともに平均流率が様々な値を取り、MFDは散らばりのある分布になることが多い。さらに、特に高速道路ネットワークなどではヒステリシスループと呼ばれる特徴的で複雑な挙動が観測されることが多い¹¹⁾など、その理論的・



(a) 3次元空間中に埋め込まれた球面状のデータ（ただし、西経 171–180 度にあたる部分は除去） (b) 同データの UMAP による次元削減結果 (c) 同データの PCA による次元削減結果

図-1: UMAP と PCA による次元削減の例

経験的性質には不明確な点が多い。

3. 分析

(1) 分析方針

本研究の方針分析は以下の通り。まず、対象とする交通システムは首都高速道路（以下、首都高と略す）と東京都主要一般道（以下、一般道と略す）の 2 種とする。期間は 2019 年 7-9 月と 2021 年 7-9 月とし、オリパラと COVID-19 という特異な事象の影響を考察できるものとする。

そして、それぞれの交通システムの各時刻の交通状態ベクトルに対し PCA, UMAP を適用し、その 2 次元表現を得る。2 次元とする理由は、これが人間が直感的に認識できる形式であるためである。UMAP にはいくつかのハイパーパラメータがあるが、結果に最も大きな影響を及ぼす $n_neighbors$ の値はデータの規模に併せて 500 とし（なお、100 より大きければ結果は大きくは変わらないことを確認した）、他はデフォルト値のままとした。さらに、首都高に対しては平均流率と平均密度に基づく MFD も計算する。一方、一般道に対してはデータの制約のため平均流率のみを計算する。そして、PCA, UMAP, 交通工学的方法を比較し、それらの性質を考察するとともに、実現象の解釈を導く。

(2) データ

本分析で用いた主なデータは以下の通り：

- 東京 2020 大会の交通・輸送に関する各種データのうち、首都高速道路上の感知器の地点 5 分間流率・速度（提供：東京都）
- 首都高感知器位置情報・ネットワーク形状データ（提供：東北大学酒井高良氏、フューチャー株式会社）

社石川裕太郎氏)

- 東京都一般道の断面交通量情報のうち、感知器の 5 分間交通量（提供：日本道路交通情報センター）
- 東京都一般道の断面交通量計測地点位置情報（提供：日本交通管理技術協会）

適切な感知器観測情報のみを用いるため、期間全体のデータ欠損率が 10% を超えた感知器はデータ分析対象から外した¹。その結果、首都高の感知器数は 1425、交通状態ベクトルの次元は 2850 となり、期間全体のベクトル数は約 25000 個となった。一般道の感知器数は 626、交通状態ベクトルの次元も同じく 626 となり、期間全体のベクトル数は首都高と同じく約 25000 個となった。

首都高で観測されたある 1 日のネットワーク交通状態の推移を図-2 に示す。深夜は交通量が極めて少ないが、8 時ごろから交通量が増え、日中は混雑し、20 時には落ち着きつつあることが直感的にわかる。しかし、混雑の詳細な構造はこの可視化結果からは明確でない。例えば、12:00 の交通状態と 16:00 のその違いは直感的には認識できない。

一般道で観測されたある 2 日の交通状態の推移を図-3 に示す。2 日とも、全体的に日中の方が交通量が多いことがわかる。しかし、こちらも交通現象の詳細な構造はこの可視化結果からは明確でない。8:00 と 16:00 の交通状態の違いや、COVID-19 前後のその違いは直感的には認識できない。

(3) 首都高

首都高の交通状態を PCA で次元削減した結果を図-4 に示す。ここで、横軸は PCA の第 1 主成分、縦軸は第 2 主成分、点は特定時刻の交通状態ベクトルの 2 次元

¹ 期間が長期間にわたるため、欠損のない感知器の性質も経年変化している可能性は排除できないが、今回はその影響は無視することとする。

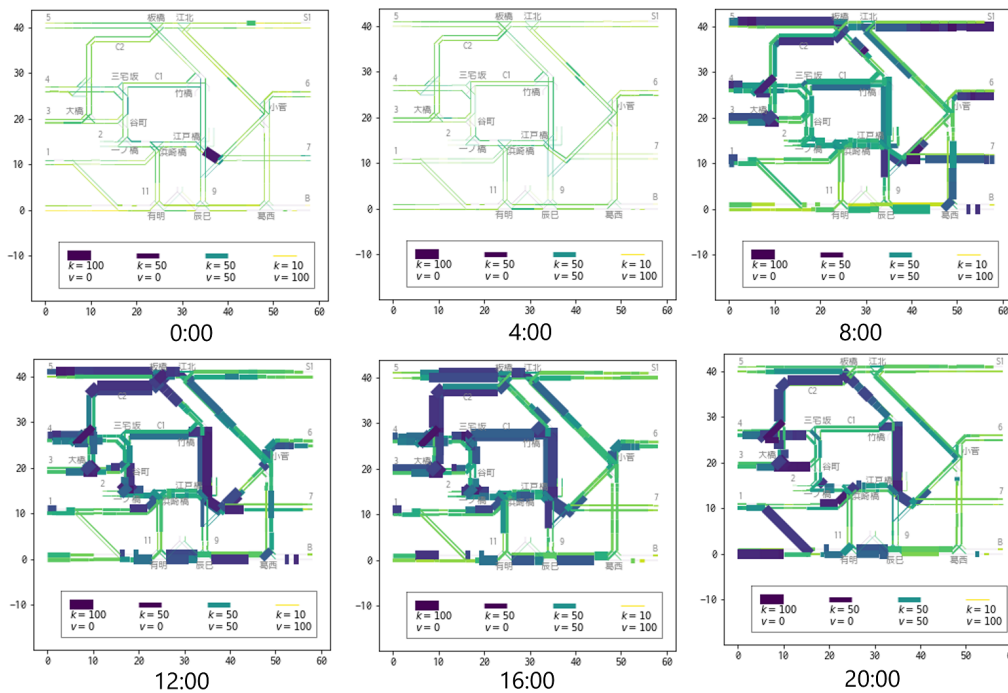


図-2: 首都高速道路の典型的な平日 (2019-07-29) のネットワーク交通状態. リンクの太さはそのリンクの感知器が観測した平均密度, 色は同じく平均速度を意味する. (ネットワークデータは酒井氏・石川氏提供のもの)

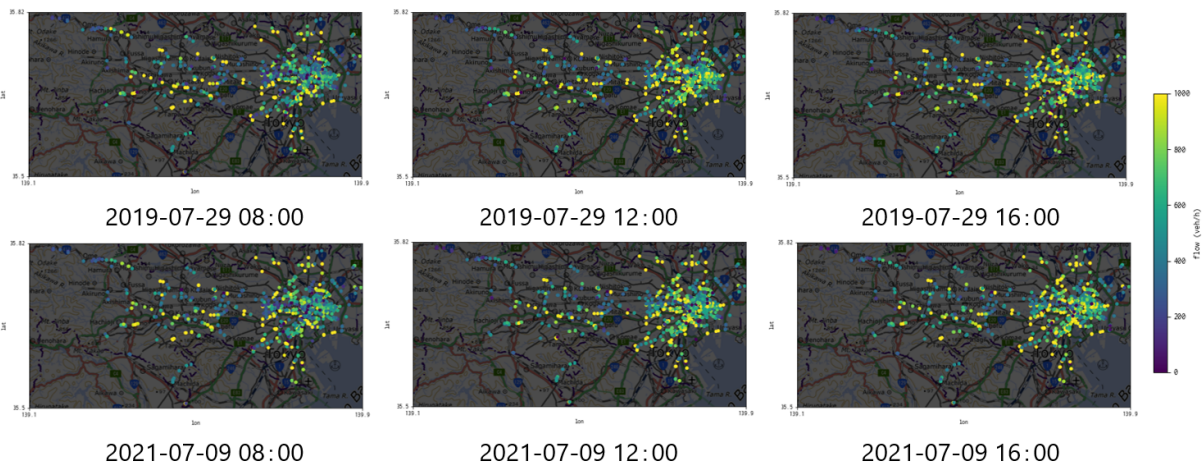



図-3: 東京都一般道の COVID-19 前・中の典型的な平日のネットワーク交通状態. 点の色はその地点の感知器が観測した流率を意味する. (背景の地図は地理院地図を加工して使用)

表現を意味する. また, 図-4a では点の色はその交通状態ベクトルが観測された時刻, 図-4b ではその平均密度を意味する². これらの図からは明確なパターンが見取れる. 図-4a からは, 交通状態の低次元表現と時刻の間に明確な関係があることがわかる. まず, 交通状態は時刻とともに以下のように推移する: 交通状態は深夜0時には左端に位置し, 朝の通勤時間帯にかけて右下に移動し, 昼~夕の帰宅時間帯にかけて右上に移動


し, また深夜に左端に戻る. また, 時間帯ごとに取りうる交通状態の幅が大きく異なる. 深夜はほぼ一点に集中しているが, 朝の通勤時間帯~夕の帰宅時間帯は同じ時刻でも取りうる交通状態には大きな幅がある.

図-4b からは, 交通状態の第1主成分は概ね平均密度と対応していることがわかる. すなわち, 左側ほど低密度, 右側ほど高密度という非常に強い傾向が存在する. これは深夜帯は低密度, 日中は高密度という事実とも一致する. また, これはMFDが平均密度を用いる

² 平均速度は平均密度とほぼ反比例していたため, 可視化結果からは省略.



(a) PCA と時刻の関係




(b) PCA と平均密度の関係


図-4: 首都高速道路の交通状態の PCA による次元削減結果

ことをデータの特性の面からも正当化するともいえる。一方で、本結果は MFD とは異なり同様な平均密度と速度を持つ朝の通勤時間帯と夕の帰宅時間帯を明確に区別できており、その意味で交通の本質的の違いを認識できていると言える。


首都高の交通状態を UMAP で次元削減した結果を図-5 に示す。先ほどと同様、図-5a は時刻、図-5b は密度で色付けした結果である。これらには、PCA の結果(図-4) と類似した点と異なる点が見いだせる。まず、類似した点として、ある日の交通状態は時刻とともに円周状の軌跡をたどって推移する点がある。すなわち、交通状態は深夜は左下に位置し、朝に右に移動し、昼から夕にかけて右上に移動し、また深夜に左下に戻るといった挙動である。また、低次元表現上でも、平均密度は非常に明確な特徴量になっていることがわかる。一方、PCA の結果と異なる点として、午前中の交通状態が大きく 2 箇所(第 1 次元の値が 12.5 付近と、5-10 付近)に分かれて分布している点がある。実は、これは平日と休日の違いであり、前者の交通状態は 12.5 付近に分布し、後者は 5-10 付近に分布している。さらに、分布のほぼ中央にデータのない穴が空いている点も特筆すべき違いである。これは、深夜の交通状態と昼間の交通状態は全く異なった特徴を持っており、その中間となる状態は存在せず、朝か夕の交通状態を経ないと連続



(a) UMAP と時刻の関係



(b) UMAP と平均密度の関係



(c) COVID-19 前 (2019 年)


(d) COVID-19 中 (2021 年)

図-5: 首都高速道路の交通状態の UMAP による次元削減結果


的变化では到達できないことを意味している。これらは PCA よりも直感に合う結果と考えられ、非線形な手法である UMAP の優位性が示唆される。また、深夜から朝の間にも空隙(第 1 次元が約 6.5-10、第 2 次元が約 1.5 の領域)が存在する。これは朝 5-6 時に相当し、この時間帯の通勤開始に伴う交通状態の変化は不連続的变化と見なせるほど急激であることを意味している。

図-5c と図-5d に COVID-19 前と中の交通状態だけをそれぞれ抽出して可視化した結果を示す。点の色は時刻であるが、より正確な値が分かりやすいように図-5a とはカラースキームを変更している点に注意されたい。両者を比較すると、COVID-19 の影響で交通状態の分布は若干は変化した、全体的な形状は大きくは変化していないことがわかる。

首都高の交通状態を MFD として表した結果を図-6 に示す。図-6a はデータをその時刻で色付けし、図-6b-図-6e は PCA や UMAP の低次元表現で色付けしたものである。図-6a を見ると、中~高密度領域ではヒステリシス現象の影響もあり、同じ密度でも時刻によって取りうる流率が異なっていることがわかる。これは酒井・赤松⁵⁾の結果とも符合する。図-6b-図-6e を見ると、密度




(a) MFD と時刻




(b) MFD と PCA 第 1 主成分

(c) MFD と PCA 第 2 主成分



(d) MFD と UMAP 第 1 次元

(e) MFD と UMAP 第 2 次元



(f) COVID-19 前 (2019 年)

(g) COVID-19 中 (2021 年)

図-6: 首都高速道路の MFD とその特徴付け

は他の手法の低次元表現と良く対応している (UMAP とは若干違いが見られる) が、流率には時刻と同様に単純な対応が見いだせない。PCA, UMAP の方がより簡潔に複雑な現象を表現できていると言える。COVID-19 前・中の MFD を比較すると (図-6f, 図-6g), COVID-19 中の方が大きな密度の交通状態の生起量が若干少ないが、大きな違いは見いだせない。

首都高のいくつかの日の交通状態の推移を PCA, UMAP, MFD 上に軌跡として可視化したものを図-7 に示す。それぞれの方法で得られた低次元表現の特徴がわかる。例えば、典型的な平日と休日と比較すると、MFD からは休日は密度が小さく速度低下が起きる密度域にまで達しないということがわかるが、PCA と UMAP では平日と比較し交通状態は全く異なる推移をしていることがわかる。

UMAP が交通の本質的な低次元表現を得られているという立場に立つと、図-7 からは以下のことが読み取れる。まず、COVID-19 前の平日と休日は全く異なる交通状態が生起している。一方、平日の交通状態は COVID-19 前と中であまり大きな違いは起きていない。オリパラ期間の交通状態は平常時のそれと若干異なるが、平常時の平日と休日の差ほど大きな違いは見られない (オリパラ初日は除く)。なお、データ期間中で最も異常が見られたのは 2019-09-09、すなわち台風 15 号が関東に上陸し、大規模な規制がかけられた日であった。

UMAP の低次元表現からは元の多次元データを復元 (逆算) できる。UMAP が適切に低次元表現を得られているか確認するために、図-8 に低次元表現から復元したリンク密度の比較結果を示す。図-8a からは、朝ピークと夕ピークでリンクの使用状況が逆転する場合が多いことがわかる。図-8b からは、休日は平日と比較しリンク密度が軒並み小さいことがわかる。いずれも直感と整合的であり、適切な低次元表現が得られていることが示唆される。

(4) 一般道

一般道の交通状態を PCA で次元削減した結果を図-9 に示す。首都高の場合と類似した結果となっている。

一般道の交通状態を UMAP で次元削減した結果を図-10 に示す。首都高の場合と比較し、非常に複雑なパターンが得られた。時刻推移の軌跡が円周状のパターンを描くのは同様であるが、その円が複数組み合わせられた複雑な形状をしている。実は、この円は平日と休日、COVID-19 前の中での組み合わせによって分かれている。これは図-10c, 図-10d, 後述する図-12 から確認できる。よって、一般道の場合は UMAP は PCA では全く見過ごされていた複雑な構造を発見できたと言える。

交通工学的な量の可視化として、図-11 に一般道の平均流率の日内変動を示す。一般的に知られている通り、日中は流率が大きくなることがわかる。COVID-19 前中を比較すると、後者の方が若干流率が小さい傾向にあるが、その差は大きくはない。

首都高のいくつかの日の交通状態の推移を PCA, UMAP, 交通量時系列図上に軌跡として可視化したものを図-12 に示す。それぞれの方法で得られた低次元表現の特徴がわかる。特に、先述した UMAP の円周の性質、すなわち平日と休日、COVID-19 前の中での組み合わせによって交通状態は異なる円周状を推移することがよくわかる。これは PCA や交通量時系列図からはわからない結果である。

UMAP が交通の本質的な低次元表現を得られているという立場に立つと、図-12 からは以下のことが読み取れる。平日と休日は全く異なる交通状態が生起した。さ

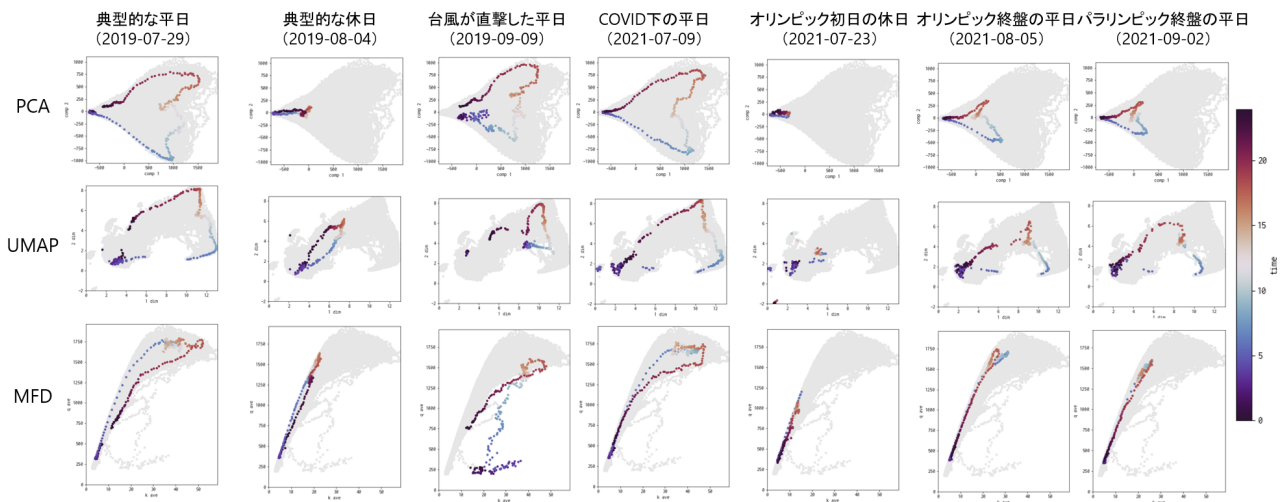



図-7: 首都高速道路のいくつかの日の次元削減された交通状態。グレーは期間全体で観測された状態，色付きの点はその日に観測された状態で，点の色は時刻を表す。MFDの密度 k_{ave} と流率 q_{ave} の単位はそれぞれ veh/km , veh/h である。




(a) COVID-19 前の 8 時と 18 時 (b) COVID-19 前の平日と休日の 8 時


図-8: 首都高速道路の典型的な交通状態の UMAP から逆算した密度比較

らに，COVID-19 前と中の平日も全く異なる交通状態が生じた。オリンピックも交通状態に大きな影響を及ぼし，概ね COVID-19 前の休日とオリンピック中の平日が類似した状態となっていた。なお，2019 年の台風 15 号は，首都高と比較して一般道には大きな影響は及ぼさなかったと言える。

UMAP が適切に低次元表現を得られているか確認するために，図-13 に低次元表現から復元した地点交通量の比較結果を示す。図-13a からは朝ピークと夕ピークで逆向きの交通が発生している傾向にはあるが，首都高ほど明確ではないことがわかる。図-13b からは COVID-19 の影響で交通量が若干減少傾向にあるが，そこまで明確ではないことがわかる。



(a) PCA と時刻の関係




(b) PCA と平均流率の関係

図-9: 東京都一般道の交通状態の PCA による次元削減結果


4. おわりに

本研究では，非常に大規模な現象である都市規模の交通流の直感的な認識のため，交通データを PCA, UMAP, MFD を用いて次元削減を行った。PCA や UMAP を用いて交通データを次元削減して解釈するという考え方は，非常に単純ではあるが既往研究での事例は見当たらない。分析では東京都の首都高速道路と主要一般道での平常時とオリパラ・COVID-19 期を含むデータを対象とし，その交通現象の直感的な解釈を導き出した。


その結果，PCA と UMAP は交通現象の複雑な違い，



(a) UMAP と時刻の関係




(b) UMAP と平均流率の関係



(c) COVID-19 前 (2019 年)

(d) COVID-19 中 (2021 年)

図-10: 東京都一般道の交通状態の UMAP による次元削減結果



(a) COVID-19 前 (2019)

(b) COVID-19 中 (2021)

図-11: 東京都一般道の平均流率の時系列図

すなわち単なる交通状態ベクトル間のユークリッド距離や MFD のような平均に基づく次元削減では表せない違いをある程度区別できた。また、非線形な手法である UMAP は線形な PCA よりさらに複雑な現象を捉えることができたと考えられる。

PCA による次元削減結果は一般に以下の性質を持っていると確認された。まず、第 1 主成分と第 2 主成分はハート状に分布する。第 1 主成分はほぼネットワーク全体の平均密度もしくは流率に対応する。第 2 主成分は午前と午後の交通の方向性の違いを表す。

UMAP による次元削減結果は一般に以下の性質を持っていると確認された。2 次元に次元縮約した場合、概ね

一つもしくは複数の円周状にデータが分布する。この円周は時刻と対応する。交通システムによっては、平日と休日や平常時と異常時で異なる円周が生起する。

UMAP が交通の本質を捉えているという立場に立って得られた結果を解釈すると、休日やオリパラと COVID-19 が東京の交通流に与えた影響は以下のようにまとめられる。首都高の交通は、平日と休日で大きく異なる状態を取った。また、オリパラ期は平常時と相当程度（休日ほどではない）異なる状態が見られた。一方、COVID-19 期（オリパラ期以外）は平常時とほぼ同じ状態であった。一般道の交通は、平日と休日、平常時とオリパラ期と COVID-19 期で大きく異なる状態を取った。これらの解釈は、MFD や平均流率に基づく考察では得難いものが多い。

今後の研究の方向性には以下が考えられる。まず、今回得られた結果の一般性を確認する、すなわち他の交通システムでの検証を進める。紙面の都合上詳細は述べられないが、著者の予備的な分析では、定性的に類似した結果が鎌倉市中心部の一般道交通流、ニューヨーク市のタクシー乗客流動に対しても得られている。仮に一般性が確認できれば、UMAP により交通現象の普遍的な規則性を効率よく適切に把握できる可能性があるため、その科学的な考察や工学的な応用が期待される。次に、今回は空間的パターンに特に着目して分析したが、時間的パターンの分析も興味深い課題である。そのためには、ある一日の異なる時刻のデータをまとめて一つの状態ベクトルとし次元削減を行う方法が有効と考えられる。最後に、予測や制御といった実用的課題への応用が考えられる。例えば、強化学習によるデータ駆動型の制御手法では、状態空間の次元を小さく保つ必要があり、大規模交通システムへの適用上大きな課題となっている¹²⁾¹³⁾。そこで、UMAP により次元削減した表現を状態ベクトルに用いれば、大規模交通システム全体の状態を適切に考慮した制御が可能になると予測される。

なお、本研究では、UMAP が交通の本質を捉えた次元削減をできているかどうかは厳密には確認しておらず、直感的な推測にとどまっている。これは、「交通の本質とは何か？」という疑問に厳密に答えるのが困難なことも理由の一つである。仮に前述のような制御や予測が有効であれば、逆説的に UMAP の次元削減で本質を捉えられると示唆される。

謝辞: 本研究は JSPS 科研費 20H02267 の助成を受けた。事例分析に用いたデータを無償提供いただいた東京都、日本道路交通情報センター、東北大学酒井高良氏、フューチャー株式会社石川裕太郎氏の各位に御礼申し上げます。

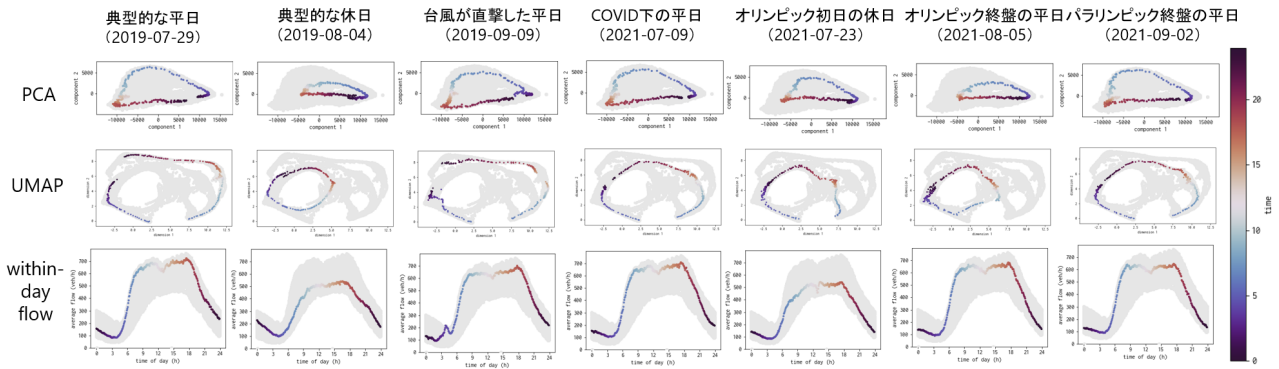
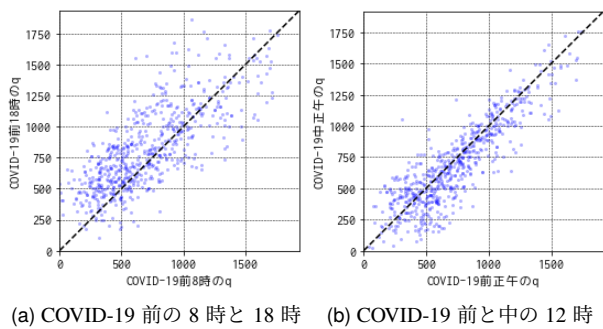


図-12: 東京都一般道のいくつかの日の次元削減された交通状態。グレーは期間全体で観測された状態，色付きの点はその日に観測された状態で，点の色は時刻を表す。



(a) COVID-19 前の 8 時と 18 時 (b) COVID-19 前と中の 12 時

図-13: 東京都一般道の典型的な交通状態の UMAP から逆算した流率比較

- 9) 飯村一実, 松岡秀一: 東京 2020 大会 交通施策の取組みと成果, 交通工学, Vol.57, No.3, pp.22–25, 2022.
- 10) 小林景: 多様体学習とデータ空間の幾何学, 数理解析研究所講究録, Vol.2057, pp.1–10, 2017.
- 11) Geroliminis, N. and Sun, J.: Hysteresis phenomena of a macroscopic fundamental diagram in freeway networks, *Transportation Research Part A: Policy and Practice*, Vol.45, No.9, pp.966–979, 2011.
- 12) 佐藤公洋, 瀬尾亨, 布施孝志: 強化学習を用いたデータ駆動型の動的混雑課金の最適化手法, 土木学会論文集 D3 (土木計画学), Vol.76, No.5, pp.I.1273–I.1285, 2021.
- 13) Sato, K., Seo, T., and Fuse, T.: Dynamic network congestion pricing based on deep reinforcement learning, *arXiv preprint arXiv: 2206.12188*, 2022.

(Received 2022-09-01)

(Accepted *)

参考文献

- 1) Mahmassani, H. S., Williams, J. C., and Herman, R.: Investigation of network-level traffic flow relationships: some simulation results, *Transportation Research Record*, Vol.971, pp.121–130, 1984.
- 2) Geroliminis, N. and Daganzo, C. F.: Macroscopic modeling of traffic in cities, *Transportation Research Board 86th Annual Meeting*, 2007.
- 3) Daganzo, C. F.: Urban gridlock: Macroscopic modeling and mitigation approaches, *Transportation Research Part B: Methodological*, Vol.41, No.1, pp.49–62, 2007.
- 4) McInnes, L., Healy, J., and Melville, J.: UMAP: Uniform manifold approximation and projection for dimension reduction, *arXiv preprint arXiv:1802.03426*, 2018.
- 5) 酒井高良, 赤松隆: 首都圏高速道路網における渋滞パターンと macroscopic fundamental diagram の安定性, 土木学会論文集 D3 (土木計画学), Vol.75, No.2, pp.97–108, 2019.
- 6) 馬場静羽, 井上亮, 酒井高良, 赤松隆: テンソル分解に基づく首都高速道路の交通渋滞時空間パターンの解明, 土木計画学研究・講演集, Vol. 65, 2022.
- 7) Seo, T., Bayen, A. M., Kusakabe, T., and Asakura, Y.: Traffic state estimation on highway: A comprehensive survey, *Annual Reviews in Control*, Vol.43, pp.128–151, 2017.
- 8) Lakhina, A., Papagiannaki, K., Crovella, M., Diot, C., Kolaczyk, E. D., and Taft, N.: Structural analysis of network traffic flows, *Proceedings of the joint international conference on Measurement and modeling of computer systems*, pp. 61–72, 2004.

Interpreting large-scale traffic flow using dimension reduction:
PCA/UMAP/MFD and case study of Tokyo Olympic-Paralympic/COVID

Toru SEO